

NÖHÜ Müh. Bilim. Derg. / NOHU J. Eng. Sci., Erken Görünüm / InPress Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi Niğde Ömer Halisdemir University Journal of Engineering Sciences

Araștırma makalesi / Research article

www.dergipark.org.tr/tr/pub/ngumuh / www.dergipark.org.tr/en/pub/ngumuh



Derin öğrenme tabanlı SNR kestirimi: Durum çalışması

Deep learning based SNR estimation: Case study

Merih Leblebici^{1,*} (1), Ali Çalhan² (1)

¹ Düzce Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 81620, Düzce, Türkiye ² Düzce Üniversitesi, Bilgisayar Mühendisliği Bölümü, 81620, Düzce, Türkiye

Öz

Sinyal-gürültü oranı (signal to noise ratio, SNR) kestirimi, uyarlanabilir modülasyonu, etkili güç tahsisini ve güvenilir bağlantı uyarlamasını iyileştirdiği için kablosuz haberleşme sistemlerinin optimize edilmesinde önemli bir yere sahiptir. Veri yardımlı ve veri yardımsız olarak yapılan geleneksel SNR kestirim yöntemlerinin, yüksek frekans, geniş bant aralığı ve gürültüye karşı duyarlılığın fazla olması şeklinde karakterize edilen altıncı nesil (sixth generation, 6G) sistemlerinde yaşadıkları zorlukların aksine derin öğrenme (deep learning, DL) modelleri umut vaat eden bir alternatif olarak karşımıza çıkmaktadır. Bu çalışmada ResNet101V2, MobileNetV2 ve Xception olmak üzere üc adet DL modelinin SNR sınıflandırma performansı, modülasyon türlerine ait yıldız diyagramı görüntüleri yardımıyla öğrenme aktarımı tekniği kullanılarak değerlendirilmiştir. ResNet101V2, %70.8'lik bir ortalama sınıflandırma doğruluyla en üstün performansı gösterirken MobileNetV2 ve Xception sırasıyla %63.6 ve %56.8'lik doğruluk değerlerine ulaşabilmektedir. ResNet101V2, yüksek dereceli modülasyon türleri kullanılarak yapılan SNR sınıflandırmasında daha dayanıklı bir mimari olduğunu göstermiş olsa da MobileNetV2, kaynakları sınırlı senaryolar için alternatif olabilecek bir işlemsel yüke sahiptir. Tüm bunların aksine Xception, ImageNet veri setindeki görüntü sınıflandırma başarısına rağmen bu çalışmaya özgü olan SNR sınıflandırmasında aynı performansı gösterememektedir. Sonuçlar beklendiği üzere artan modülasyon derecesiyle beraber sınıflandırma doğruluğunun düştüğünü göstermektedir.

Anahtar kelimeler: SNR kestirimi, Kablosuz haberleşme, Derin öğrenme, Öğrenme aktarımı

1 Giriş

Sinyal-gürültü oranı (signal to noise ratio, SNR) kestirimi, kablosuz haberleşme sistem performanslarının optimize edilmesi için önemli bir işlemdir. SNR bilgisinin doğru bir şekilde elde edilmesi uyarlanabilir modülasyonu, etkin güç tahsisini ve güvenilir bağlantı uyarlamasını mümkün kılar. Altıncı nesil (sixth generation, 6G) teknolojisindeki güncel gelişmeler veri iletim hızının 938 Gbps (Gigabit per second, saniye başına Gigabit) değerlerine ulaşmasını sağlayarak beşinci nesil (fifth generation, 5G) ağlarındaki kapasitenin de üstüne çıkmıştır [1]. Benzeri görülmemiş bu veri hızları SNR kestiriminde yeni zorluklar

Abstract

Signal-to-noise ratio (SNR) estimation plays a critical role in optimizing wireless communication systems by enabling adaptive modulation, efficient power allocation, and reliable link adaptation. Traditional SNR estimation methods, whether data-aided or data-assisted, face significant challenges in sixth generation (6G) systems due to their high frequency, wide bandwidth, and heightened sensitivity to noise. In response to these challenges, deep learning (DL) models have emerged as a promising alternative. This study evaluates the SNR classification performance of three DL models-ResNet101V2, MobileNetV2, and Xception-utilizing transfer learning with star diagram images representing modulation types. The results indicate that ResNet101V2 achieves the highest classification accuracy of 70.8%, demonstrating robustness in handling high-order modulation types. MobileNetV2 achieves an accuracy of 63.6%, offering a viable alternative for resource-constrained scenarios due to its computational efficiency. In contrast, Xception, despite its established success in image classification tasks such as those on the ImageNet dataset, performs poorly in SNR classification with an accuracy of 56.8%. This disparity underscores the specificity of SNR classification as a unique challenge distinct from general image classification tasks. Additionally, as expected, classification accuracy declines with increasing modulation order, reflecting the complexity of higher-order modulations.

Keywords: SNR estimation, Wireless communication, Deep learning, Transfer learning

meydana getirmektedir çünkü yüksek frekanslar ve bant genişlikleri gürültü ve girişime karşı olan hassasiyeti artırır. Geleneksel SNR kestirim yöntemleri bu durumlar altında zorluk yaşamakta ve 6G sistemlerinde güvenilir bir haberleşmenin sağlanabilmesi için yenilikçi yaklaşımlara ihtiyaç duyulmaktadır.

Geleneksel SNR kestirim yöntemleri veri yardımlı olup olmamasına göre iki gruba ayrılabilir. Veri yardımlı SNR kestirim yönteminde iletilen veri ön bilgi olarak kullanılırken [2], veri yardımsız SNR kestirim yönteminde ise doğrudan alınan sinyal analiz edilerek SNR kestirilmeye çalışılır [3]. Ancak SNR kestirim yöntemleri sıklıkla iletim ortamının

^{*} Sorumlu yazar / Corresponding author, e-posta / e-mail: merihleblebici@duzce.edu.tr (M. Leblebici) Geliş / Received: 27.02.2025 Kabul / Accepted: 21.04.2025 Yayımlanma / Published: xx.xx.20xx doi: 10.28948/ngumuh.1647805

doğrusal olmaması, çok yollu sönümleme, girişim ve gerçek zamanlı senaryolarla karakterize edilebilecek zorluklarla karşılaşabilir.

Derin öğrenme (deep learning, DL) modellerinin gelişmesiyle beraber çeşitli teknikler, sinyal ve modülasyon sınıflandırma [4–6] ile kanal kestirimi [7] gibi farklı alanlarda sıklıkla kullanılmaya başlanmıştır. Güçlü özellik çıkarma yeteneği sayesinde DL modelleri SNR kestirimi problemi için de uygulanmış ve geleneksel yöntemlere göre kestirim performansının iyileştiği görülmüştür [8,9].

DL modellerinin gelişmesiyle beraber desen tanımlama ve özellik çıkarma gibi konularda büyük başarılar elde edilmiştir. Bu çalışmada DL modellerinin SNR kestirimindeki performansı yıldız diyagramlarından yararlanarak doğrudan ham sinyaller üzerinden elde edilen görüntülerle araştırılmaktadır. Böylelikle özelliklerin el ile ayarlanmasının ya da kanal modelleri hakkında geniş varsayımlarda bulunmanın önüne geçilmiş olunur.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir: Bölüm 2'de SNR kestirimi ile ilgili literatür taraması verilerek yapılacak katkı sunulmuştur. Bölüm 3'te literatüre yapılacak katkının nasıl olacağı açıklanmıştır. SNR kestirimi için önerilen modele ait simülasyon çıkarımları Bölüm 4'te yer alırken Bölüm 5'te çalışmanın sonucu ve potansiyel çalışma konuları verilmiştir.

2 İlgili çalışmalar

Yukarıda da belirtildiği üzere geleneksel SNR kestirim yöntemleri veri yardımlı ve veri yardımsız olmak üzere iki gruba ayrılmaktadır. Veri yardımlı kestirimler, en küçük ortalama karesel hata (minimum mean square error, MMSE), en büyük olabilirlik (maximum likelihood, ML) ve karesel sinyal-gürültü varyansı (signal-to-noise variance, SNV) kestirimcileri olmak üzere iletilen veriye ait ön bilgiye ihtiyaç duymaktadır [10-12]. ML tabanlı SNR kestirimci ilk olarak [13]'teki calısmayla toplamsal beyaz Gauss gürültüsü (additive white Gaussian noise, AWGN) iceren kanal icin faz kaydırmalı anahtarlama (phase shift keying, PSK) modülasyon ailesinden ikili PSK (binary PSK, BPSK) türü kullanılarak önerilmiştir. İlk olarak Pauluzzi vd. [14] tarafından BPSK modülasyon türü için önerilen SNV tabanlı SNR kestirimci ise sonrasında daha yüksek modülasyon dereceleri için geliştirilmiştir.

Veri yardımı olmadan yapılan SNR kestirimlerinde ise herhangi bir ön bilgi sahibi olunmadan sadece alınan sinyal üzerinden kestirim işlemi gerçekleştirilir. İkinci ve dördüncü dereceden moment (second and fourth-order moment, M2M4) kestirim yöntemiyle bölünmüş sembol moment kestirimcisi (split-symbol moment estimator, SSME) ve sinyal-varyasyon oranı (signal-to-variation ratio, SVR) kestirimcisi veri yardımsız SNR kestirim yöntemlerine örnek olarak verilebilir [3,15,16]. AWGN kanalda BPSK için SSME SNR kestirimi ilk olarak [17]'de önerilmiştir. PSK modülasyon türleri için optimize edilen ve diğer modülasyon türleri için uygun olmayan SVR SNR kestirimcisi ise Brandão vd. tarafından AWGN kanal için önerilmiştir [18].

Geleneksel SNR kestirim yöntemlerinin bazı kısıtlarından dolayı performansları yeterli seviyede değildir. Örneğin bazı yöntemler sınırlı sayıda modülasyon türü için optimize edildiği için diğer modülasyon türlerine uygulanmak istendiği zaman performansları düşük kalmaktadır. Ayrıca bazı yöntemlerde düşük SNR seviyelerinin kestiriminde zorluklar yaşanmaktadır. Son olarak da tüm bu yöntemler alınan sinyalin mükemmel bir senkronizasyon içinde alındığını ve verici-alıcı arasında zaman ve faz kaymasının olmadığını varsaymaktadır ki bu varsayımların pratik senaryolar için geçerliliği mümkün değildir. Bunların önüne geçmek için ise DL tabanlı SNR kestirim yöntemleri önerilmiştir.

Mevcut DL tabanlı SNR kestirim yöntemleri genellikle es fazlı ve karesel (in-phase and quadrature, IQ) değerlerinden oluşan sinyalleri kullanır. Örneğin Yang vd. [19] sinyalin IQ değerlerinin kullanıldığı basit bir evrişimli sinir ağı (convolutional neural network, CNN) tabanlı SNR kestirim yöntemi önermiş ve geleneksel yöntemlere göre daha ivi bir performansa sahip olduğunu göstermişlerdir. Ngo vd. [9] ise uzun vadeli evrim (long term evolution, LTE) ve 5G haberleşme sistemleri için CNN ile uzun kısa-süreli bellek (long short-term memory, LSTM) modellerinin birlikte kullanıldığı bir SNR kestirim yöntemi önermişlerdir. Bu yöntem, geleneksel yöntemlere göre daha iyi bir doğruluk değerine sahip olmasına rağmen çok az SNR aralığı için hazırlanmış bir veri seti üzerinden eğitilmiş olması dolayısıyla kısıtlı bir performans göstermektedir. Bir diğer calısma olan [8]'de ise DL modeli, yıldız diyagramları ile beslenmis ve ivi bir doğruluk değerine ulasmıştır ancak bu çalışmada da sınırlı bir SNR aralığı dikkate alınmıştır.

Li vd. [20] çerçeve temelli bir SNR kestirim yöntemini araştırmışlardır. Bu yöntemde LSTM'nin yanında yinelemeli sinir ağlarından (recurrent neural network, RNN) da yararlanılmıştır. Bilişsel radyolar (cognitive radio, CR) için spektrumun izlenmesi büyük önem taşımaktadır. Boş olan bantlar, ikincil kullanıcıların kullanımı sırasında herhangi bir çakışma yaşamamaları için tespit edilmektedir. Jeevangi vd. [21] CR ağlarındaki spektrumun izlenmesi için DL tabanlı bir SNR kestirim yöntemi önermişlerdir. Zheng vd. [22] ise güç spektrumunu giriş olarak kullanıldığı DL tabanlı bir SNR kestirim tekniği üzerinde çalışmışlardır. Güç spektrumunu giriş olarak kullanmalarının işlemsel yükü azalttığını göstermişlerdir.

Chen vd. [23] DL ve kovaryans matrisini birleştiren bir SNR kestirim metodu önermişlerdir. Bu metotta kovaryans matrisi CNN'nin girişi olarak kullanılır. Yaptıkları karşılaştırmalarda önerilen metot, düşük ve orta SNR değerlerinde diğer modellere göre üstün bir performans sergilerken yüksek SNR değerlerinde diğerleriyle yaklaşık sonuçlar vermiştir. Bunu yaparken diğer DL tabanlı kestirim yöntemlerine göre daha düşük işlemsel karmaşıklığa sahip oldukları öne çıkmaktadır.

Xu vd. ise [24] klasik SNR kestirim tekniklerindeki düşük doğruluk değerlerini iyileştirmek için dikkat mekanizmaları ve LSTM'den yararlanarak yeni bir mimari önermişlerdir. Önerilen mimarinin diğerlerine göre performansının daha iyi olduğu gösterilmiştir. Son olarak Hu vd. [25] SNR kestirimi için güç spektrumundan yararlanan yeni bir DL modeli önermişlerdir. Önerilen model AWGN, Rayleigh ve Rician gibi kanal durumları için test edilmiş ve diğer modellere göre yüksek SNR değerlerinde daha iyi bir performans sergilemiştir.

Bu çalışmada ise literatürden farklı olarak -20 dB ile 20 dB arasındaki geniş bir aralık için SNR kestirim modeli önerilmiştir. Bu SNR aralığındaki veri seti, IQ verilerinden yararlanılarak yıldız diyagramı görüntüleri şeklinde oluşturulmuştur. Veri seti içerisinde yer alan modülasyon türlerinin arasında dördün PSK (quadrature PSK, QPSK), 8PSK, 16PSK, 32PSK ile karesel genlik modülasyonu (quadrature amplitude modulation, QAM) modülasyon ailesinden QAM16, QAM64 ve QAM256 yer almaktadır. Bu modülasyon türlerine ait IQ görüntüleri üzerinden CNN tabanlı bir SNR kestirimi yapılmaktadır

3 Yöntem

Bu çalışma için üretilen veri seti yedi adet modülasyon türünü içermektedir. Her bir modülasyon türü, -20 dB ile 20 dB arasındaki SNR aralığını 5 dB aralıklarla kapsar. Her bir SNR değeri için 500 adet olmak üzere modülasyon türü başına 4500 adet görüntü düşmektedir. Eğitim sırasında her bir modülasyon türüne ait 4500 adet görüntü %80'i eğitim, %10'u doğrulama ve %10'u test verisi olarak ayrılmaktadır.

Veri setini oluşturacak modülasyon türleri QPSK, 8PSK, 16PSK, 32PSK, QAM16, QAM64 ve QAM256 olmak üzere seçilmiştir. Belirlenen SNR değeriyle üretilen AWGN, ilgili modülasyon türüne eklenir ve her bir modülasyon türüne ait görüntüler IQ değerlerinden oluşan yıldız diyagramlarını içerecek şekilde oluşturulur. Şekil 1'de veri setinde yer alan modülasyon türleri gösterilmiştir. Çalışma kapsamında üretilen ve SNR kestirimi için kullanılan veri seti üzerinde sadece AWGN etkisi bulunurken sönümleme, frekans kayması vb. diğer bozucu etkiler dikkate alınmamıştır.

Tablo 1. DL	modellerine ait	katman	yapıları
			-

	Giriş Katmanı (-, 512, 512, 3) 0			
	Ölçekleme (-, 512, 512, 3) 0			
MobileNetV2 (-, 16, 16, 1280) 2257984	ResNet101V2 (-, 16, 16, 2048) 42626560	Xception (-, 16, 16, 2048) 20861480		
Düzleştirme (-, 327680) 0	Düzleş (-, 524 0	știrme 4288)		
Yoğun KatmanYoğun Katman(-, 256)(-, 256)83886336134217984				
dense_1 (Dense) (None, 9) 2313				

Performanslarını kanıtlamış mevcut DL mimarilerinden yararlanabilmek için öğrenme aktarımı (transfer learning) tekniği kullanılarak önceden ImageNet veri setiyle eğitilmiş modeller SNR sınıflandırma işlemi için seçilmiştir. Önceden eğitilmiş bu modellerin özellikle üst katmanları, öğrendikleri özellik çıkarma kabiliyetlerini muhafaza edebilmeleri için dondurulur. Daha sonra ise önerilen modele ait sınıflandırma katmanları SNR sınıflandırmasını yapmaları için eklenir. Böylelikle öğrenme aktarımı tekniği kullanılarak önerilen modeller, SNR sınıflandırması gibi özel görevlere kolaylıkla uyum sağlarken farklı veri setinden elde ettikleri ön bilgilerden de yararlanırlar.

Sahip oldukları derin hiverarsik mimarilerinden dolavı görüntü sınıflandırma gibi görevler için uyumlu olan MobileNetV2, ResNet101V2 ve Xception modelleri bu çalışma kapsamında kullanılmıştır. Buna karar verilirken ilgili modellerin ImageNet veri seti üzerindeki Top-1 doğruluk değerlerine ve parametre sayılarına bakılarak düşük, orta ve yüksek performans gösteren modellerin seçilmesi sağlanmıştır. Öncelikle ilgili modellerin temel evrişim katmanları dondurulmuştur. Böylelikle dondurulan katmanlara ait ağırlıklarının eğitim sırasında güncellenmesinin önüne geçilir. Daha sonra modellere ait dondurulan katmanlar ile yoğun (dense) katmanlar birleştirilerek Tablo 1'de çıktı boyutları ve parametreleri gibi detayları verilen yeni bir model oluşturulur.

Öğrenme aktarımı kullanılarak önerilen sınıflandırma modelinin temel amacı hesaplama yükünü azaltmaktır. Bunun için MobileNetV2, ResNet101V2 ve Xception modellerine ait dondurulmuş katmanlara, bu katmanlara ait çıktılara göre görüntüleri sınıflandırmaya yarayan yoğun katmanlar dahil edilerek gelistirilmistir. Tablo 1'de görüldüğü üzere görüntü verisine ait 0-255 arasındaki kırmızı, yeşil, mavi (red, green, blue, RGB) değerleri 0-1 arasında olacak şekilde yeniden ölçeklendirilir. Yeniden ölçeklendirilen veriler daha sonra ilgili modellerin dondurulmuş katmanlarını besler ve çıktıları düzleştirme işleminden geçirilir. Bunun arkasına yoğun katmanların dahil edilmesiyle verinin boyutu kademeli olarak azaltılır. Softmax aktivasyon fonksiyonuna sahip son yoğun katmanla beraber SNR değerlerine karşılık gelen olasılık değerleri çıktı olarak alınmış olur.

Yukarıda verilen modellerin seçilmesinin altında yatan sebepler için büyük ölçekli görüntüleri işlemedeki etkinlikleri, işlemsel verimlilikleri ve yüksek boyutlu özellik çıkarma yeterlilikleri söylenebilir. SNR sınıflandırmasındaki en iyi doğruluğu ve genelleştirilebilirliği sağlayan mimariyi belirlemek için modeller arasında karşılaştırmalı simülasyonlar yapılmıştır.

Tüm görüntüler, giriş formatını standart hale getirmek için bir ön işlemden geçer ve 512x512 piksel olacak şekilde tek bir boyuta ayarlanır. Eğitim aşaması, model performansını en iyi hale getirmek için titizlikle belirlenen hiperparametreler kullanılarak gerçeklestirilir. En fazla 50 dönem (epoch) sürecek şekilde ayarlanan eğitim süreci, doğrulama kaybı arka arkaya 5 dönem iyileşmediği takdirde erkenden durdurulur. Yığın boyutu (batch size) 16 olarak ayarlanmış ve veri artırma (data augmentation) ya da dropout (veri azaltma) teknikleri kullanılmamıştır. Modeli optimize etmek için kök ortalama karesel yayılımı (root mean squared propagation, RMSprop) ve kayıp fonksiyonu olarak da seyrek kategorik çapraz entropi (sparse categorical crossentropy) tercih edilmiştir. Bu parametrelere karar verilmeden önce birçok farklı parametre üzerinden performans değerlendirmesi yapılmıştır. Bunların arasından optimum

sonucu verecek şekilde yukarıda bahsedilen parametreler ile modellerin sınıflandırma performansları elde edilmiştir. Bunu yaparken doğruluk değeri ve hesaplama yükü arasında bir ödünleşim gözetilerek en uygun parametrelerde karar kılınmıştır. Veri artırma ve azaltma teknikleri, sınıflandırma modellerinde karşılaşılan yetersiz veri seti ve aşırı öğrenme sorunları için sıklıkla kullanılmaktadır. Özellikle veri artırma tekniği görüntü sınıflandırması için bir nevi gürültü eklemek



Şekil 1. Veri setinde yer alan modülasyon türleri

anlamına gelmektedir. Bu çalışmada parametrelere karar vermeden önce yapılan analizlerde her iki tekniğin de performansı ya değiştirmediği ya da düşürdüğü görülmüştür. Görüntüyü döndürme, çevirme vb. veri artırma teknikleri veri setimizdeki görüntülere uygulandığında düşük SNR değerlerindeki yüksek benzerlik oranları, görüntüleri artık tamamen ayırt edilemez hale getirmektedir. Bu nedenle çalışmamızda bu tekniklerden yararlanılmamıştır ancak gelecek çalışmalarda bunlara ait klasik tekniklerden başka, ilgilenilen probleme özel teknikler geliştirilebilir.

Eğitim aşamasındaki sayısal kararlılığı koruyabilmek için tüm görüntüler normalize edilmiştir ve tüm modeller önceden eğitilmiş ağırlıklar kullanılarak sürece başlamışlardır. Doğrulama kaybı, aşırı öğrenmeyi engellemek ve modelin yakınsayacağı optimum dönemi sürekli belirlemek için izlenmistir. Modellerin performansları doğruluk değerleri, karışıklık matrisleri ve alıcı işlem karakteristik (receiver operating characteristic, ROC) eğrileri kullanılarak belirlenmiştir. Bu metrikler sınıflandırmanın performansını genel olarak analiz etmeye yararken farklı SNR değerleri ve modülasyon türleri boyunca yapılan kestirimlere ait çeşitli çıkarımlar yapmayı sağlamaktadır.

4 Simülasyon çıkarımları

Çalışma kapsamındaki simülasyonlar için Keras ve Tensorflow kütüphaneleri kullanılmıştır. Sınıflandırma modelleri çalıştırılırken Intel i7 13700KF merkezi işlem birimi (central processing unit, CPU), 32 GB rastgele erişimli bellek (random access memory, RAM) ve tek bir NVIDIA GeForce RTX 4070Ti grafik işlem birimi (graphics processing unit, GPU) gibi donanım ekipmanlarından yararlanılmıştır.

Yedi adet modülasyon türüne ait -20 ile 20 dB arasındaki SNR sınıflandırma performansı üç adet derin öğrenme modeli ile incelenmistir. Bu incelemelerden elde edilen sonuçlar karışıklık matrisleri, ROC eğrileri ve sınıflandırma

doğrulukları (classification accuracy) üzerinden karşılaştırılmıştır.

Şekil 2'de modülasyon türlerine göre SNR sınıflandırma doğrulukları gösterilmektedir. Her bir çubuk ilgili modülasyon türü için sınıflandırma modelinin ulaştığı doğruluk değerini ifade etmektedir.

ResNet101V2, en yüksek sınıflandırma doğruluklarını elde ederek tüm modülasyon türlerinde diğer iki modele karşı üstünlük sağlamıştır. Özellikle QPSK ve QAM16 modülasyon türlerinde ciddi bir avantaj sergilemektedir. MobileNetV2, ikinci en iyi sınıflandırma doğruluğuna sahiptir ve çoğu modülasyon türünde Xception'a göre daha iyi performans göstermektedir. Xception ise tüm modülasyon türlerinde en düşük doğruluk değerini elde ettiği için SNR sınıflandırma problemi için etkili bir model olmadığı anlaşılmaktadır.

QPSK ve QAM16 için elde edilen sınıflandırma doğrulukları 32PSK ve QAM256 gibi yüksek dereceli modülasyon türleri için elde edilen sınıflandırma doğruluklarından daha yüksektir. Bu eğilim, yüksek dereceli modülasyon türlerinin artan karmaşıklık ve azalan semboller arası mesafeden dolayı sınıflandırma problemleri için daha zorlayıcı olduğu genel beklentisi ile uyumludur. Yüksek dereceli modülasyon türleri için ResNet101V2, diğer modellere göre daha ivi performansa sahip olmaya devam etmekte ama özellikle cok zorlayıcı bir modülasyon türü olan QAM256 için aradaki fark ciddi ölçüde azalmaktadır.

QPSK için ResNet101V2, %76.4 doğruluk değerine ulaşarak MobileNetV2 (%68.2) ve Xception (%59.1) modellerine göre üstün bir performans göstermektedir. En karmaşık modülasyon türü olan QAM256 icin ResNet101V2, %61.3 doğruluk değerine ulaşırken MobileNetV2 ve Xception aradaki farkı kapatmasına rağmen geride kalmaya devam edip sırasıyla %60.7 ve %53.3 doğruluk değerlerine sahip olmaktadır.



Şekil 2. SNR sınıflandırma doğrulukları

Şekil 3'te PSK ailesi modülasyon türlerine ait karışıklık matrisleri verilmektedir. Her bir karışıklık matrisi, satırlarda yer alan asıl sınıflar (true label) ile sütunlarda yer alan tahmini sınıflar (predicted label) arasındaki ilişkiyi görselleştirmektedir. Matrislerdeki köşegen (diagonal) hücreler doğru tahminleri ifade etmektedir. QPSK için MobileNetV2, özellikle 0'dan düşük SNR değerlerinden dolayı ortalama bir SNR sınıflandırma doğruluğu sergilemektedir. ResNet101V2, başarılı bir sınıflandırma performansı göstermektedir.



Şekil 3. PSK ailesi modülasyon türlerine ait karışıklık matrisleri

MobileNetV2'de %100 ve ona yakın değerlerdeki doğruluk oranlarında altı adet SNR değeri varken ResNet101V2'de bu sayı yediye çıkmaktadır. Xception ise diğer modellere göre kötü bir performansa sahiptir.

8PSK için MobileNetV2, QPSK'ya benzer bir sınıflandırma performansı göstermektedir. ResNet101V2'nin performansı üç modele göre en iyisiyken yine Xception en kötü sınıflandırma doğruluğuna sahip olmaktadır.

MobileNetV2 için yanlış sınıflandırma oranları 16PSK'da artmaktadır. Diğer modülasyon türlerine göre performansı düşse de ResNet101V2 diğer modellere göre hala üstün performans göstermektedir. Xception için ise düşük sınıflandırma oranları devam etmektedir.

32PSK modülasyon türüyle beraber MobileNetV2'nin performansı daha da düşmektedir. ResNet101V2 diğer

modellere göre üstün bir performans göstermesine rağmen yanlış sınıflandırma oranlarının da arttığı gözden kaçmamalıdır. Xception ise en kötü performansı sergilemekte ve yüksek dereceli modülasyon türlerinde daha fazla zorluk çektiği görülmektedir.

Şekil 4'te ise QAM ailesi modülasyon türlerine ait karışıklık matrisleri verilmektedir. PSK ailesinde olduğu gibi en iyi performansı ResNet101V2 gösterirken MobileNetV2 ortalama bir doğruluk değerine sahiptir. Xception ise en kötü performansı göstermeye devam etmektedir. Yine beklendiği gibi modülasyon derecesi arttıkça karmaşıklığın getirdiği sorunlar ortaya çıkmakta ve tüm modellerin performansı belli bir oranda düşmektedir.



Şekil 4. QAM ailesi modülasyon türlerine ait karışıklık matrisleri

Şekil 5'te PSK ailesine ait ROC eğrileri verilmektedir. Sınıflandırma modelleri karşılaştırılırken kullanılan bir başka metrik olan ROC eğrilerinin x ekseninde yanlış pozitif oran (false positive rate, FPR) yer alırken y ekseninde doğru pozitif oran (true positive rate, TPR) yer almaktadır. Eğri altındaki alan (area under the curve, AUC) ise ilgili modelin sınıfları ayırt etme kabiliyetini gösteren nicel bir ölçüm sunmaktadır. Bu ölçüm değeri ne kadar 1'e yakınsa yani eğrinin altında kalan alan ne kadar büyükse modelin o kadar iyi bir performansa sahip olduğu anlaşılmaktadır. Tüm modeller için QPSK modülasyon türünde, en fazla eğri üst-sol köşeye (iyi bir sınıflandırma performansının göstergesi) yaklaşarak en yüksek AUC değerlerini elde etmektedir. Bunların arasında da ResNet101V2, birbirine yakın eğrilerle beraber ideal noktaya en fazla yaklaşarak diğer modellere üstünlük kurmaktadır. Modülasyon dereceleri arttıkça ROC-AUC değerleri genel olarak azalmasına rağmen en iyi ve en kötü değerlere sırasıyla ResNet101V2 ve Xception sahip olurken MobileNetV2 ortalama bir değer kümesine sahip olmaktadır.



Şekil 5. PSK ailesi modülasyon türlerine ait ROC eğrileri

Şekil 6'da ise QAM ailesine ait ROC eğrileri verilmektedir. QAM16 için tüm modeller 1'e yakın en fazla AUC değerine sahip olarak iyi bir sınıflandırma performansı göstermektedir. Eğrilerin dikliğinin fazla olması ve ideal noktaya yakınlığı yüksek doğruluk değerini yansıtmaktadır. QAM64 ve QAM256 ile beraber sınıflandırma problemi daha zorlayıcı olmaktadır. Bundan dolayı da ROC eğrileri yayılmakta ve bazı SNR değerleri için daha düşük AUC değerlerine sahip olmaktadır. QAM256 özelinde ise sembollerin yakınlığı sınıflandırma problemini daha da zor hale getirmekte ve düşük SNR değerleri için ideal noktadan çok uzakta eğriler oluşmaktadır. Sınıflandırma modelleri arasındaki performans sıralaması ise tüm modülasyon türleri için iyiden kötüye doğru ResNet101V2, MobileNetV2 ve Xception olarak gerçekleşmektedir.

Tablo 2'de en yüksek doğruluk oranına sahip ResNet101V2'ye ait performans metrikleri gösterilmektedir. Doğruluk değerleri her bir modülasyon türüne ait SNR değerlerinin doğru sınıflandırma doğruluk oranlarını göstermektedir. Kesinlik (precision) değerinin yüksek olması modelin çok az yanlış pozitif (false positive, FP) değerlendirme yaptığını göstermektedir. Yüksek duyarlılık (recall) ise modelin çok az yanlış negatif (false negative, FN) değerlendirme yaptığı anlamına gelmektedir. F1 değeri de kesinlik ile duyarlılığın harmonik ortalamasını ifade eder ve yüksek değerlerde olması veri setinin dengeli dağıldığını ve modelin bir metriği diğerine göre üstün görmediğini belirtmektedir.

Modülasyon derecesi artıkça performansın kötüleştiği bu metriklerde de kendini göstermektedir. Bunun yanında 0 dB ve üstü SNR değerlerine ait kesinlik ve duyarlılık metrikleri yüksek ve birbirine yakındır. Bu durum kesinlik ve duyarlılık arasında iyi bir dengenin sağlandığını ve modelin ne çok korumacı ne de çok agresif bir tutum sergilediğini göstermektedir. Yani ortalama bir performans yakalamak için modelin doğru tespitler yapma pahasına FP kararları vermekten kaçınmadığını ifade etmektedir.



Şekil 6. QAM ailesi modülasyon türlerine ait ROC eğrileri

		-20 dB	-15 dB	-10 dB	-5 dB	0 dB	5 dB	10 dB	15 dB	20 dB
	Doğruluk	0.88	0.90	0.93	0.89	0.93	1.00	1.00	1.00	1.00
QPSK	Kesinlik	0.45	0.53	0.65	0.67	0.61	1.00	1.00	1.00	0.98
	Duyarlılık	0.28	0.78	0.80	0.04	0.98	1.00	1.00	1.00	1.00
	F1 Değeri	0.35	0.63	0.71	0.08	0.75	1.00	1.00	1.00	0.99
	Doğruluk	0.90	0.80	0.91	0.87	0.96	1.00	1.00	1.00	0.99
8DCL	Kesinlik	0.63	0.34	0.67	0.23	0.79	1.00	1.00	1.00	0.96
01 SK	Duyarlılık	0.34	0.84	0.44	0.06	0.88	0.96	1.00	1.00	0.96
	F1 Değeri	0.44	0.49	0.53	0.10	0.83	0.98	1.00	1.00	0.96
	Doğruluk	0.92	0.76	0.88	0.89	0.95	1.00	1.00	1.00	1.00
16DSV	Kesinlik	0.88	0.31	0.42	NaN	0.80	1.00	0.96	1.00	1.00
101 3K	Duyarlılık	0.30	0.94	0.28	0.00	0.78	0.96	1.00	1.00	1.00
	F1 Değeri	0.45	0.47	0.34	0.00	0.79	0.98	0.98	1.00	1.00
	Doğruluk	0.91	0.90	0.88	0.90	0.90	1.00	1.00	1.00	1.00
32DSK	Kesinlik	0.64	0.64	0.49	0.62	0.53	1.00	1.00	1.00	1.00
52F 5K	Duyarlılık	0.42	0.28	0.92	0.16	0.94	1.00	1.00	1.00	1.00
	F1 Değeri	0.51	0.39	0.64	0.25	0.68	1.00	1.00	1.00	1.00
	Doğruluk	0.90	0.86	0.92	0.86	0.96	1.00	1.00	1.00	0.99
0AM16	Kesinlik	0.55	0.41	0.60	0.17	0.87	1.00	1.00	1.00	0.91
QAMIO	Duyarlılık	0.66	0.48	0.74	0.06	0.80	1.00	1.00	1.00	1.00
	F1 Değeri	0.60	0.44	0.66	0.09	0.83	1.00	1.00	1.00	0.95
QAM64	Doğruluk	0.89	0.90	0.89	0.70	0.94	1.00	1.00	1.00	1.00
	Kesinlik	0.52	0.69	0.50	0.26	0.88	1.00	1.00	1.00	1.00
	Duyarlılık	0.32	0.18	0.02	0.88	0.58	1.00	1.00	1.00	1.00
	F1 Değeri	0.40	0.29	0.04	0.40	0.70	1.00	1.00	1.00	1.00
	Doğruluk	0.85	0.90	0.86	0.72	0.92	0.99	1.00	1.00	0.99
OAM256	Kesinlik	0.26	1.00	0.40	0.23	0.93	0.93	1.00	1.00	1.00
QAIVI230	Duyarlılık	0.18	0.08	0.42	0.68	0.26	1.00	1.00	1.00	0.90
	F1 Değeri	0.21	0.15	0.41	0.35	0.41	0.96	1.00	1.00	0.95

Tablo 2. ResNet101V2'ye ait performans metrikleri

Üç model arasında gerçekleştirilecek olası bir ödünleşim durumunda Tablo 3'ten yararlanılabilir. Bu tabloda modellere ait mimari karakteristiklerin yansıtıldığı, MB cinsinden boyut, parametre sayısı ve derinlik ile performans değerlerini yansıtan ImageNet veri seti üzerindeki sınıflandırma doğruluğu ve yapılan çalışmaya özgü SNR sınıflandırma doğruluğu gibi bilgiler yer almaktadır.

MobileNetV2, boyut ve parametre sayısı bakımından en küçük model olması nedeniyle kaynakları kısıtlı cihazlarda kullanımı daha doğru olacaktır ancak bu sınırlı kapasitesi, performansının diğer büyük modellere göre düşük kalmasına yol açmaktadır.

ResNet101V2, MobileNetV2'ye göre boyut olarak oldukça büyük ve daha derin bir model olduğundan dolayı daha iyi özellik çıkarma yeteneğine sahiptir. Boyut ve parametre sayısı değerleri işlemsel karmaşıklık ile performans arasında bir ödünleşim yapmayı gerektirmektedir.

Xception ise boyut ve parametre sayısı bakımından MobileNetV2 ile ResNet101V2'nin arasında yer alıp orta düzeyde bir performansı makul olarak nitelendirilebilecek bir karmaşıklıkla sunmaktadır.

Xception, ImageNet veri seti üzerinde %79.0 ile en iyi doğruluk değerine ulaşırken onu %77.2 ile ResNet101V2 ve %71.3 ile MobileNetV2 takip etmektedir. Bu metrik, modellerin büyük ölçekli görüntü sınıflandırma problemlerinde gösterdikleri genelleştirme kapasitelerini yansıtmaktadır. Çalışma kapsamında belirlenen probleme bakıldığı zaman ise ResNet101V2'nin %70.8 ile en yüksek SNR sınıflandırma doğruluğuna ulaştığı görülmektedir. Bu sefer ResNet101V2'yi MobileNetV2 ve Xception sırasıyla %63.6 ve %56.8 doğruluk oranlarıyla takip etmektedir. Bu durum, Xception'ın ImageNet veri setinde iyi performans göstermesine rağmen sahip olduğu mimariden dolayı bu çalışmaya özgü belirlenen SNR sınıflandırma problemine etkili bir şekilde uyum sağlayamayarak başarılı olamadığını göstermektedir. Her iki durum icin de ivi değerlendirilebilecek performans değerleriyle öne çıkan ResNet101V2'nin sahip olduğu derin yapıdan dolayı işlemsel karmaşıklığının fazla olacağı gözden kaçırılmaması gereken bir husustur.

Öğrenme aktarımı yöntemiyle önerilen DL sınıflandırma modellerinin eğitim süreçleri aşırı öğrenme durumuna karşı

	Tablo 3.	Kullanılan	modeller	arasındaki	ödünlesim	tablosu
--	----------	------------	----------	------------	-----------	---------

Model	Boyut (MB)	Parametre Sayısı	Derinlik	ImageNet Sınıflandırma Doğruluğu	SNR Sınıflandırma Doğruluğu (Ortalama)
MobileNetV2	14	3.5 M	105	%71.3	%63.6
ResNet101V2	171	44.7 M	205	%77.2	%70.8
Xception	88	22.9 M	81	%79.0	%56.8

dikkatli bir şekilde takip edilmiştir. Tablo 1'de değerleri verilen yoğun katmanların parametre sayıları oldukça yüksektir. Bu durum aşırı öğrenme ve hesaplama yükü gibi konularda ciddi zorluklar yaratabilir. Sınıflandırma katmanları kademeli olarak eklenerek nihayetinde sınıflandırılacak etiket sayısına kadar düşürülür. Bu eklenen katmanların sayısına bağlı olarak sondaki etiket sayısına yumuşak ya da sert bir geçiş yapılabilir. Yumuşak geçişte daha fazla katman eklenerek daha düşük parametre sayıları elde edilebilirken bu çalışmada tercih edilen sert geçişte daha az katman eklenerek yüksek parametre sayıları tercih edilmiştir. Böylelikle modelin derinliği ve parametre sayısı arasında bir ödünleşim yakalanmaya çalışılmıştır. Bu yapılırken yukarıda da bahsedildiği gibi eğitim süreci aşırı öğrenme durumuna karşı izlenmiştir.

Modelin eğitim süreci kayıp değerleri art arda 5 dönem iyileşmezse durdurulmuştur. Ayrıca Şekil 7'de QAM16 modülasyon türü için eğitim ve doğrulama setlerine ait doğruluk ve kayıp değerleri bulunmaktadır. Kayıp grafiklerine bakılacak olursa doğrulama setine ait değerlerin hızlı bir şekilde düşük değerlere yakınsadığı ve belli bir dönem dalgalandıktan sonra stabil hale geldiği görülmektedir.



Şekil 7. QAM16 modülasyon türüne ait doğruluk ve kayıp değerleri

5 Sonuçlar

Bu çalışmada öğrenme aktarımı tekniği kullanılarak sınıflandırma konusundaki başarıları literatürde kanıtlanmış olan üç adet DL modelinin SNR sınıflandırma performansı çeşitli modülasyon türleri için araştırılmıştır. ResNet101V2, SNR sınıflandırma problemi için en etkili model olarak çıkmakta ve tüm modülasyon türlerinde ortaya MobileNetV2 ve Xception'ın önüne geçmektedir. Karışıklık matrislerinden de görülebileceği üzere ResNet101V2'nin köşegen hücrelerdeki üstünlüğü ve diğer modellere göre daha az yanlış sınıflandırma yapmış olması modelin dayanıklılığını göstermektedir. Bunun aksine MobileNetV2, daha az islemsel yük gerektirmesine rağmen ortalama bir performans sergilemekte ve kaynakların sınırlı olduğu senaryolar için uygun bir seçenek olarak ortaya çıkmaktadır. Xception ise ImageNet veri seti kullanılarak gerçekleştirilen görüntü sınıflandırma probleminde göstermiş olduğu başarıya bu çalışmaya özgü olan modülasyon türlerinin görüntüleri kullanılarak yapılan SNR sınıflandırmasında ulaşamamıştır. Bundan dolayı mimari yapısının ilgili probleme göre tekrar uyarlanmasına ihtiyaç duymaktadır. Tüm modülasyon türlerinden elde edilen SNR sınıflandırma doğruluklarının ortalaması alındığı zaman en iyi performansın %70.8 ile ResNet101V2'ye ait olduğu görülebilir. Onu %63.6 ile MobileNetV2 takip ederken %56.8 ile de Xception'ın en kötü doğruluk oranını elde ettiği söylenebilir.

Tüm modeller için SNR sınıflandırma performansının modülasyon derecesinin yükselmesiyle beraber düştüğü görülmektedir. Bunun nedeni olarak semboller arası mesafenin azalması ve gürültüye karşı duyarlılığın artması söylenebilir. Gelecek çalışmalarda bu zorlukların üstesinden gelmek adına yüksek dereceli modülasyon türleri için veri teknikleriyle beraber modellere artırma ait hiperparametrelerin optimizasyonu üzerinde çalışılabilir. ResNet101V2, ileri öğrenme aktarımı teknikleri ve optimizasyon işlemleri için güçlü bir temel oluşturabilir. Ayrıca birçok yöntemin hibrit olarak kullanılması ve çeşitli yapılması sınıflandırma optimizasyon işlemlerinin performansını oldukça iyileştirecektir. Bunun yanında veri setimizin sadece AWGN etkisinde üretilmiş olması çalışmanın kısıtlarından biri olarak ortaya çıkmaktadır. Sönümleme, frekans kayması vb. bozucu etkilerle genişletilerek üretilecek bir veri seti bu kısıtı ortadan kaldıracak bir çalışma konusu olabilir.

Ayrıca çalışma kapsamında öğrenme aktarımı prensibiyle önerilen modeller kendi aralarında karşılaştırılmış olup literatürdeki diğer klasik ya da DL tabanlı SNR kestirim teknikleriyle herhangi bir karşılaştırma yapılmamıştır. Çalışmamıza ait bir diğer kısıt olarak görülebilecek bu hususa gelecek çalışmalarda değinilecektir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %10

Kaynaklar

- Z. Zhou, A. Kassem, J. Seddon, E. Sillekens, I. Darwazeh, P. Bayvel, Z. Liu, 938 Gb/s, 5–150 GHz ultra-wideband transmission over the air using combined electronic and photonic-assisted signal generation, Journal of Lightwave Technology, 42(20), 7247–7252, 2024. https://doi.org/10.1109/JLT.2024. 3446827.
- [2] H. Abeida, T. Y. Al-Nafouri, S. Al-Ghadhban, Dataaided SNR estimation in time-variant Rayleigh fading channels. In 2010 IEEE 11th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC), IEEE, pp. 1–5, 2010. https://doi.org/10.1109/SPAWC.2010.5671005.
- [3] R. Matzner, F. Englberger, An SNR estimation algorithm using fourth-order moments. In Proceedings of 1994 IEEE International Symposium on Information Theory, IEEE, pp. 119, 1994. https://doi.org/10.1109 /ISIT.1994.394869.
- [4] T. Xu, I. Darwazeh, Wavelet classification for noncooperative non-orthogonal signal communications. In 2020 IEEE Globecom Workshops, GC Wkshps 2020-Proceedings, Institute of Electrical and Electronics Engineers Inc., pp. 1-6, 2020. https://doi.org/10.1109 /GCWkshps50303.2020.9367556.
- [5] Y. Liu, H. Du, D. Niyato, J. Kang, Z. Xiong, D.I. Kim, A. Jamalipour, Deep generative model and its applications in efficient wireless network management: A tutorial and case study, IEEE Wireless Communications, pp. 199-207, 2024. https://doi.org/ 10.1109/MWC.009.2300165.
- [6] H. Ye, L. Liang, G. Y. Li, B. H. Juang, Deep learningbased end-to-end wireless communication systems with conditional GANs as unknown channels, IEEE Transactions on Wireless Communications, 19(5), 3133–3143, 2020. https://doi.org/10.1109/TWC.2020 .2970707.
- [7] S. M. Aldossari, K. C. Chen, Machine learning for wireless communication channel modeling: An overview. Wireless Personal Communications, 106, 41–70, 2019. https://doi.org/10.1007/s11277-019-06275-4.
- [8] X. Xie, S. Peng, X. Yang, Deep learning-based signalto-noise ratio estimation using constellation diagrams, Mobile Information Systems 2020(1), 8840340, 2020. https://doi.org/10.1155/2020/8840340.
- [9] T. Ngo, B. Kelley, P. Rad, Deep learning based prediction of signal-to-noise ratio (SNR) for LTE and 5G systems, In 2020 8th International Conference on Wireless Networks and Mobile Communications (WINCOM), IEEE, pp. 1–6, 2020. https://doi.org /10.1109/WINCOM50532.2020.9272470.
- [10] D. Athanasios, G. Kalivas, SNR estimation for low bit rate OFDM systems in AWGN channel, In International Conference on Networking, International Conference on Systems and International Conference on Mobile Communications and Learning Technologies (ICNICONSMCL'06), IEEE, pp. 198-

198, 2006. https://doi.org/10.1109/ICNICONSMCL. 2006.198.

- [11] D. Guo, Y. Wu, S. Shamai, S. Verdú, Estimation in Gaussian noise: Properties of the minimum meansquare error, IEEE Transactions on Information Theory 57(4), 2371–2385 2011. https://doi.org/10.1109/TIT. 2011.2111010.
- [12] S.K. Tiwari, P.K. Upadhyay, Maximum likelihood estimation of SNR for diffusion-based molecular communication, IEEE Wireless Communications Letters 5(3), 320-323, 2016. <u>https://doi.org/10.1109</u> /LWC.2016.2553034.
- [13] R. Gagliardi, C. Thomas, PCM data reliability monitoring through estimation of signal-to-noise ratio, IEEE Transactions on Communications 16(3), 479– 486, 1968. <u>https://doi.org/10.1109/TCOM.1968.108</u> 9851.
- [14] D. R. Pauluzzi, N.C. Beaulieu, A comparison of SNR estimation techniques for the AWGN channel, IEEE Transactions on Communications 48(10), 1681–1691, 2000. https://doi.org/10.1109/26.871393.
- [15] T. Salman, A. Badawy, T. M. Elfouly, T. Khattab, A. Mohamed, Non-data-aided SNR estimation for QPSK modulation in AWGN channel, In 2014 IEEE 10th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob), IEEE, pp. 611-616, 2014. https://doi.org /10.1109/WiMOB.2014.6962233.
- [16] B. Shah, S. Hinedi, The split symbol moments SNR estimator in narrow-band channels, IEEE transactions on aerospace and electronic systems, 26(5), 737-747, 1990. <u>https://doi.org/10.1109/7.102709</u>.
- [17] M. K. Simon, A. Mileant, SNR estimation for the baseband assembly, The Telecommunications and Data Acquisition Report, 1986.
- [18] A. L. Brandao, L. B. Lopes, D. C. McLemon, In-service monitoring of multipath delay and cochannel interference for indoor mobile communication systems, In Proceedings of ICC/SUPERCOMM'94 - 1994 International Conference on Communications, IEEE, pp. 1458–1462, 1994. https://doi.org/10.1109/ICC. 1994.368788.
- [19] K. Yang, Z. Huang, X. Wang, F. Wang, An SNR estimation technique based on deep learning, Electronics, 8(10), 1139, 2019. https://doi.org/10.3390 /electronics8101139.
- [20] H. Li, D.L. Wang, X. Zhang, G. Gao, Frame-level signal-to-noise ratio estimation using deep learning, In Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH, International Speech Communication Association, pp. 4626–4630, 2020. https://doi.org /10.21437/Interspeech.2020-2475.
- [21] S. Jeevangi, S. Jawaligi, V. Patil, Deep Learning-based SNR Estimation for Multistage Spectrum Sensing in Cognitive Radio Networks, Journal of Telecommunications and Information Technology, (4), 21–31, 2022. https://doi.org/10.26636/jtit.2022.1649 22.

- [22] S. Zheng, S. Chen, T. Chen, Z. Yang, Z. Zhao, X. Yang, Deep Learning-Based SNR Estimation, IEEE Open Journal of the Communications Society, (5), 4778-4796, 2024. https://doi.org/10.1109/OJCOMS.2024. 3436640.
- [23] S. Chen, S. Zheng, Z. Yang, T. Chen, Z. Zhao, X. Yang, Deep Learning-Based SNR Estimation with Covariance Input, In International Conference on Communication Technology Proceedings, ICCT, Institute of Electrical and Electronics Engineers Inc., pp. 181–187, 2023 https://doi.org/10.1109/ ICCT59356.2023.10419442.
- [24] B. Xu, T. Ding, L. Guo, AC-BiLSTM: A Spatial Bidirectional LSTM with Multi-Head Self-Attention for SNR Estimation, In 2024 4th International Conference on Computer Systems, ICCS 2024, Institute of Electrical and Electronics Engineers Inc., pp. 34–38, 2024. https://doi.org/10.1109/ICCS62594. 2024.10795825.
- [25] D. Hu, Y. Zhao, W.J. Xie, Q. Xiao, L. Li, A squeezeand-excitation network for SNR estimation of communication signals, IET Communications, 19(1) 2025. https://doi.org/10.1049/cmu2.70006.

